8. Foliensatz Betriebssysteme

Prof. Dr. Christian Baun

Frankfurt University of Applied Sciences
(1971–2014: Fachhochschule Frankfurt am Main)
Fachbereich Informatik und Ingenieurwissenschaften
christianbaun@fb2.fra-uas.de

Lernziele dieses Foliensatzes

- Am Ende dieses Foliensatzes kennen/verstehen Sie...
  - die Schritte des **Dispatchers** (Prozessumschalter) beim Prozesswechsel
  - was **Scheduling** ist
    - wie **präemptives** und **nicht-präemptives Scheduling** funktioniert
    - die Arbeitsweise verschiedener **Scheduling-Verfahren**
    - wie das **Scheduling moderner Betriebssysteme** im Detail funktioniert

Im SS2019 habe ich alle Scheduling-Algorithmen (SJF/SRTF/LJF/LRTF/HRRN) von meinen Vorlesungsmaterialien gelöscht, bei denen für jeden Prozess bekannt sein muss, wie lange er bis zu seiner Terminierung braucht, also wie lange seine Abarbeitungszeit ist. Das ist in der Realität praktisch nie der Fall ($\Longrightarrow$ **unrealistisch**)

Übungsblatt 8 wiederholt die für die Lernziele relevanten Inhalte dieses Foliensatzes

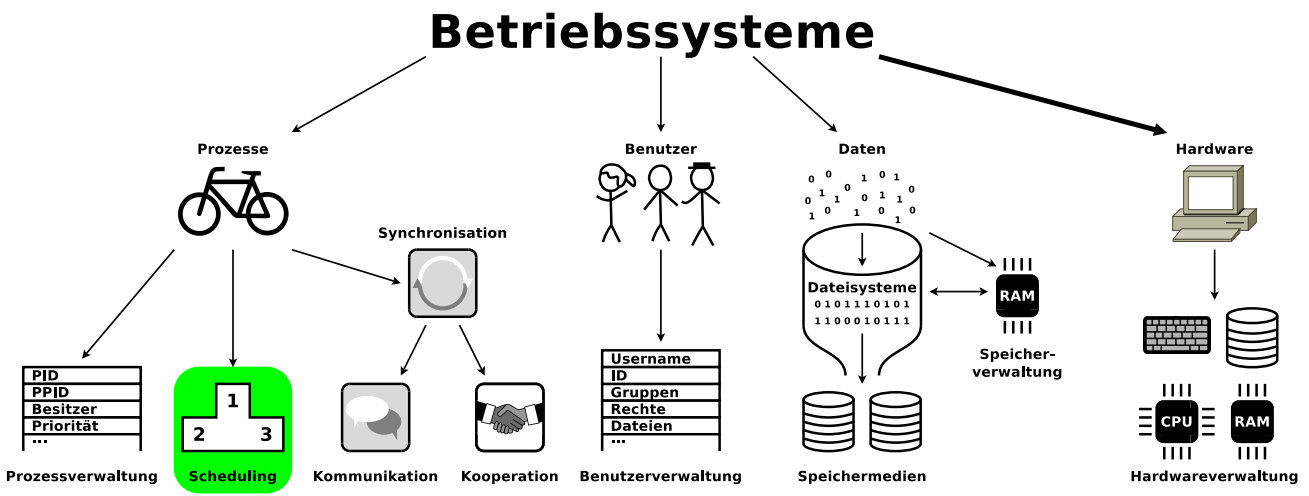

Prozesswechsel – Der Dispatcher (1/2)

- Aufgaben von Multitasking-Betriebssystemen sind u.a.:
  - **Dispatching**: Umschalten des Prozessors bei einem Prozesswechsel
  - **Scheduling**: Festlegen des Zeitpunkts des Prozesswechsels und der Ausführungsreihenfolge der Prozesse
- Der **Dispatcher** (Prozessumschalter) führt die Zustandsübergänge der Prozesse durch

Wir wissen bereits...

- Beim Prozesswechsel entzieht der Dispatcher dem rechnenden Prozess die CPU und teilt sie dem Prozess zu, der in der Warteschlange an erster Stelle steht
- Bei Übergängen zwischen den Zuständen `bereit` und `blockiert` werden vom Dispatcher die entsprechenden Prozesskontrollblöcke aus den Zustandslisten entfernt neu eingefügt
- Übergänge aus oder in den Zustand `rechnend` bedeuten immer einen Wechsel des aktuell rechnenden Prozesses auf der CPU

Beim Prozesswechsel in oder aus dem Zustand `rechnend`, muss der Dispatcher...

- den Kontext, also die Registerinhalte des aktuell ausgeführten Prozesses im Prozesskontrollblock speichern (retten)
- den Prozessor einem anderen Prozess zuteilen
- den Kontext (Registerinhalte) des jetzt auszuführenden Prozesses aus seinem Prozesskontrollblock wieder herstellen

Prozesswechsel – Der Dispatcher (2/2)

Der Leerlaufprozess (*System Idle Process*)

- Bei Windows-Betriebssystemen seit Windows NT erhält die CPU zu jedem Zeitpunkt einen Prozess
- Ist kein Prozess im Zustand `bereit`, kommt der **Leerlaufprozess** zum Zug
- Der Leerlaufprozess ist immer aktiv und hat die niedrigste Priorität
- Durch den Leerlaufprozesses muss der Scheduler nie den Fall berücksichtigen, dass kein aktiver Prozess existiert
- Seit Windows 2000 versetzt der Leerlaufprozess die CPU in einen stromsparenden Modus
- Für jeden CPU-Kern (in Hyperthreading-Systemen für jede logische CPU) existiert ein Leerlaufproze

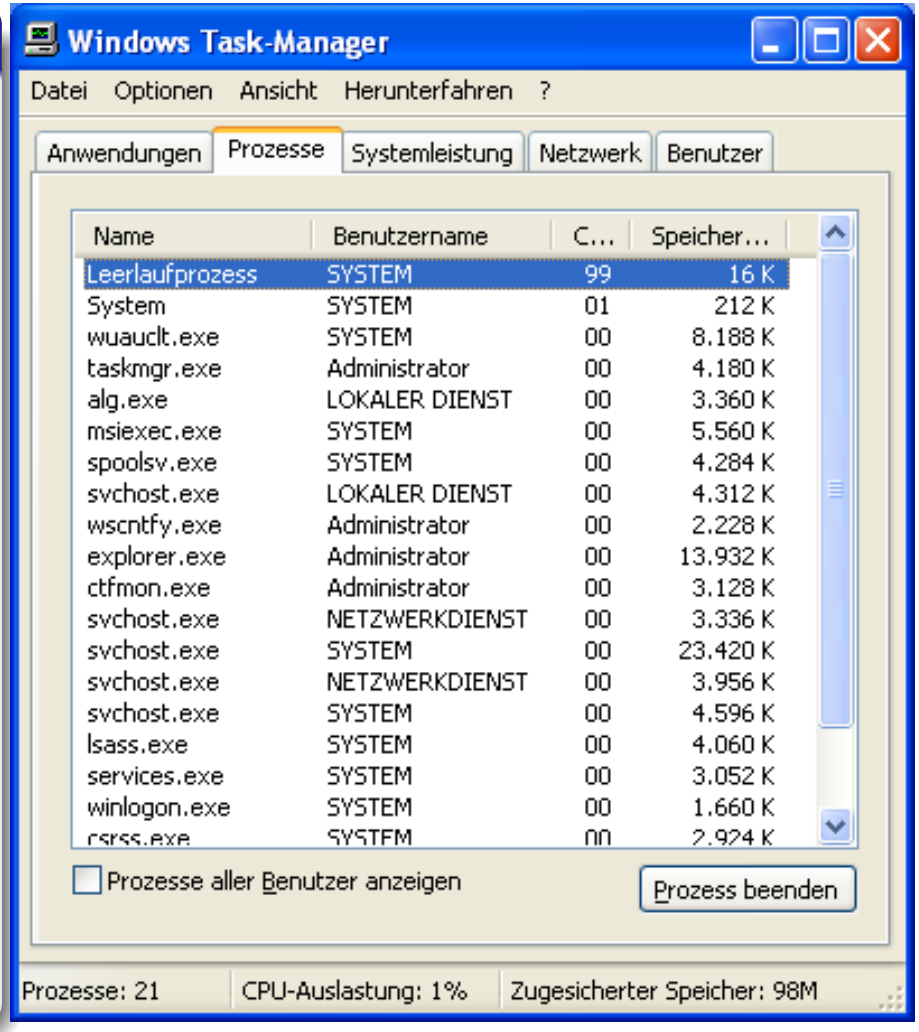

`https://unix.stackexchange.com/questions/361245/what-does-an-idle-cpu-process-do`

„In Linux, one idle task is created for every CPU and locked to that processor; whenever there's no other process to run on that CPU, the idle task is scheduled. Time spent in the idle tasks appears as "idle" time in tools such as top. . . "

Scheduling-Kriterien und Scheduling-Strategien

- Beim Scheduling legt des Betriebssystem die Ausführungsreihenfolge der Prozesse im Zustand `bereit` fest
- **Keine Scheduling-Strategie...**
  - **ist für jedes System optimal geeignet**
  - **kann alle Scheduling-Kriterien optimal berücksichtigen**
    - Scheduling-Kriterien sind u.a. CPU-Auslastung, Antwortzeit (Latenz), Durchlaufzeit (*Turnaround*), Durchsatz, Effizienz, Echtzeitverhalten (Termineinhaltung), Wartezeit, Overhead, Fairness, Berücksichtigen von Prioritäten, Gleichmäßige Ressourcenauslastung...
- Bei der Auswahl einer Scheduling-Strategie muss immer ein **Kompromiss** zwischen den Scheduling-Kriterien gefunden werden

Nicht-präemptives und präemptives Scheduling

- 2 Klassen von Schedulingverfahren existieren
  - **Nicht-präemptives Scheduling** bzw. **Kooperatives Scheduling** (nicht-verdrängendes Scheduling)
    - Ein Prozess, der vom Scheduler die CPU zugewiesen bekommen hat, behält die Kontrolle über diese bis zu seiner vollständigen Fertigstellung oder bis er die Kontrolle freiwillig wieder abgibt
    - Problematisch: Ein Prozess kann die CPU so lange belegen wie er will

Beispiele: Windows 3.x, MacOS 8/9, Windows 95/98/Me (für 16-Bit-Prozesse)

  - **Präemptives Scheduling** (verdrängendes Scheduling)
    - Einem Prozess kann die CPU vor seiner Fertigstellung entzogen werden
    - Wird einem Prozess die CPU entzogen, pausiert er so lange in seinem aktuellen Zustand, bis der Scheduler ihm erneut die CPU zuteilt
    - Nachteil: Höherer Overhead als nicht-präemptives Scheduling
    - Die Vorteile von präemptivem Scheduling, besonders die Beachtung von Prozessprioritäten, überwiegen die Nachteile

Beispiele: Linux, MacOS X, Windows 95/98/Me (für 32-Bit-Prozesse), Windows NT (inkl. XP/Visa/7/8/10/11), FreeBSD

Einfluss auf die Gesamtleistung eines Computers

- Wie groß der Einfluss des verwendeten Schedulingverfahrens auf die Gesamtleistung eines Computers sein kann, zeigt dieses Beispiel
  - Die Prozesse P_A und P_B sollen nacheinander ausgeführt werden

Prozess	**CPU-Zeit**
A	24 ms
B	2 ms

- Läuft ein Prozess mit kurzer Laufzeit vor einem Prozess mit langer Laufzeit, **verschlechtern** sich Laufzeit und Wartezeit des langen Prozesses **wenig**
- Läuft ein Prozess mit langer Laufzeit vor einem Prozess mit kurzer Laufzeit, **verschlechtern** sich Laufzeit und Wartezeit des kurzen Prozesses **stark**

Reihenfolge	**Laufzeit**		**Durchschnittliche Laufzeit**	**Wartezeit**		**Durchschnittliche Wartezeit**
	A	**B**		**A**	**B**	
P_A, P_B	24 ms	26 ms	$\frac{24+26}{2} = 25$ ms	0 ms	24 ms	$\frac{0+24}{2} = 12$ ms
P_B, P_A	26 ms	2 ms	$\frac{2+26}{2} = 14$ ms	2 ms	0 ms	$\frac{0+2}{2} = 1$ ms

Scheduling-Verfahren

- Zahlreiche Scheduling-Verfahren (Algorithmen) existieren
  - Jedes Scheduling-Verfahren versucht unterschiedlich stark, die bekannten Scheduling-Kriterien und -Grundsätze einzuhalten
- Bekannte Scheduling-Verfahren:
  - **Prioritätengesteuertes Scheduling**
  - **First Come First Served** (FCFS) bzw. **First In First Out** (FIFO)
  - ~~**Last Come First Served** (LCFS)~~
  - **Round Robin** (RR) mit Zeitquantum
  - ~~**Shortest/Longest Job First** (SJF/LRTF)~~
  - ~~**Shortest/Longest Remaining Time First** (SRTF/LRTF)~~
  - ~~**Highest Response Ratio Next** (HRRN)~~
  - **Earliest Deadline First** (EDF)
  - **Fair-Share-Scheduling**
  - ~~**Statisches Multilevel-Scheduling**~~
  - **Multilevel-Feedback-Scheduling**
  - **Completely Fair Scheduler** (CFS)
  - **Earliest Eligible Virtual Deadline First** (EEVDF)

Betriebssysteme implementieren häufig mehrere Schedulingverfahren

- In Linux z.B. gehört jeder Prozess zu einer bestimmten Prozessklasse
- Für **„Echtzeitprozesse“**...
  - `SCHED_FIFO` (Prioritätengesteuertes Scheduling, nicht-unterbrechend)
  - `SCHED_RR` (unterbrechend)
  - `SCHED_DEADLINE` (EDF-Scheduling, unterbrechend)
- Für **„normale“ Prozesse**...
  - `SCHED_OTHER` (Time-Sharing-Betrieb normaler Prozesse) realisiert als:
    - Multilevel Feedback Scheduling (bis Kernel 2.4)
    - O(1)-Scheduler (Kernel 2.6.0 bis 2.6.22)
    - Completely Fair Scheduler (Kernel 2.6.23 bis Kernel 6.5.13)
    - Earliest Eligible Virtual Deadline First scheduler (Kernel 6.6)

```
$ ps a | grep okular
 359675 pts/2    Sl     0:04 okular bts_WS2122_slideset_08_en.pdf
$ chrt -p 359675
pid 359675's current scheduling policy: SCHED_OTHER
pid 359675's current scheduling priority: 0
```

```
  SCHED_OTHER:      chrt -o -p PRIO PID
  SCHED_FIFO:       chrt -f -p PRIO PID
  SCHED_RR:         chrt -r -p PRIO PID
  SCHED_DEADLINE:   chrt -d -sched-runtime NS -sched-deadline NS -sched-period NS 0 PID
```

„A SCHED_DEADLINE task should receive *runtime* microseconds of execution time every *period* microseconds, and these *runtime* microseconds are available within *deadline* microseconds from the beginning of the period.“
Quelle: `https://www.kernel.org/doc/Documentation/scheduler/sched-deadline.txt`

Prioritätengesteuertes Scheduling

- Prozesse werden nach ihrer Priorität (= Wichtigkeit bzw. Dringlichkeit) abgearbeitet
- Es wird immer dem Prozess im Zustand `bereit` die CPU zugewiesen, der die höchste Priorität hat
  - Die Priorität kann von verschiedenen Kriterien abhängen, z.B. statische (zugewiesene) Prioritätsstufe, benötigte Ressourcen, Rang des Benutzers, geforderte Echtzeitkriterien, usw.
- Kann **präemptiv** (verdrängend) und **nicht-präemptiv** (nicht-verdrängend) sein
- Die Prioritätenvergabe kann **statisch** oder **dynamisch** sein
  - Statische Prioritäten ändern sich während der gesamten Lebensdauer eines Prozesses nicht und werden häufig in Echtzeitsystemen verwendet
  - Dynamische Prioritäten werden von Zeit zu Zeit angepasst
    $\Longrightarrow$ **Multilevel-Feedback Scheduling** (siehe Folie 21)
- Gefahr beim (statischen) prioritätengesteuertem Scheduling: Prozesse mit niedriger Priorität können verhungern ($\Longrightarrow$ **nicht fair**)
- Prioritätengesteuertes Scheduling eignet sich für interaktive Systeme

Prioritätengesteuertes Scheduling

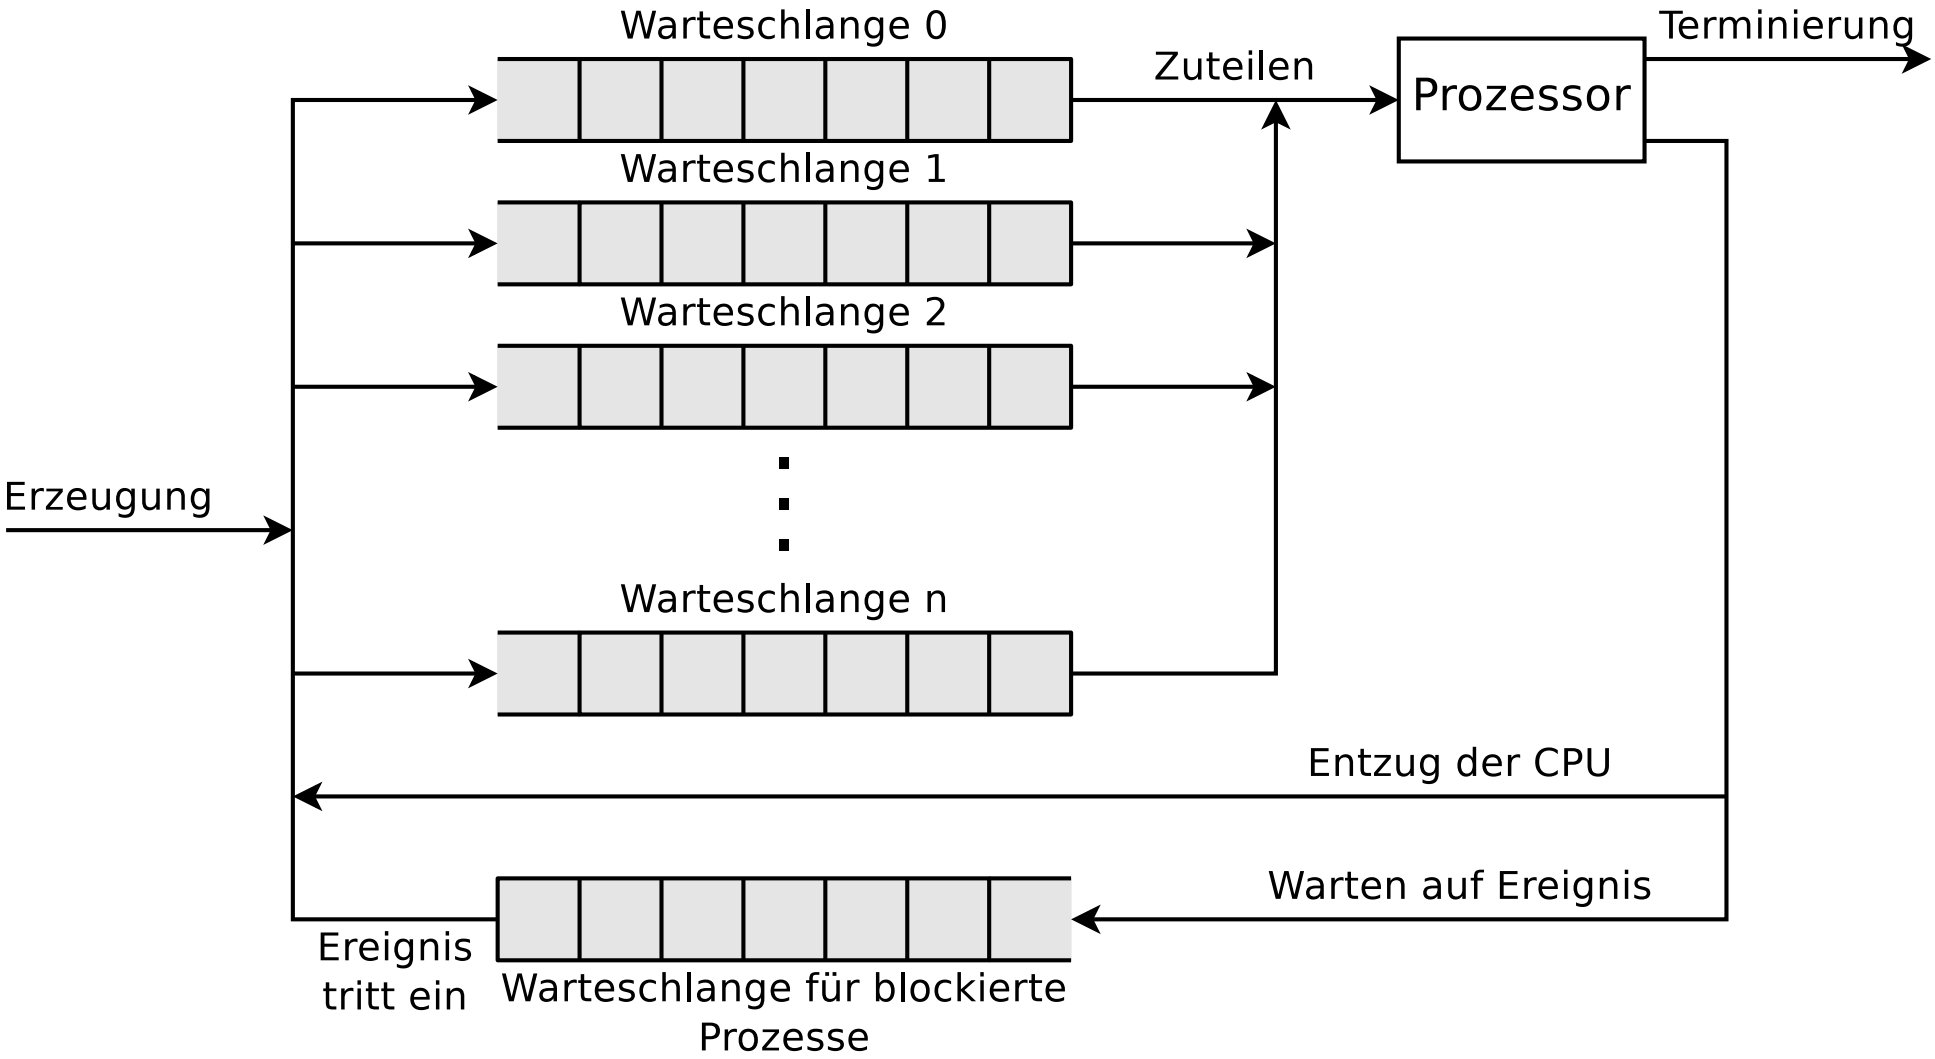

Quelle: William Stallings. Betriebssysteme. 4. Auflage. Pearson (2003). S.465

Beispiel zum Prioritätengesteuerten Scheduling

- Auf einem Einprozessorrechner (mit nur einem CPU-Kern) sollen 4 Prozesse verarbeitet werden
- Alle Prozesse sind zum Zeitpunkt 0 im Zustand `bereit`
- Ausführungsreihenfolge der Prozesse als Gantt-Diagramm (Zeitleiste)

Prozess	Rechenzeit	Priorität
A	8 ms	3
B	4 ms	15
C	7 ms	8
D	13 ms	4

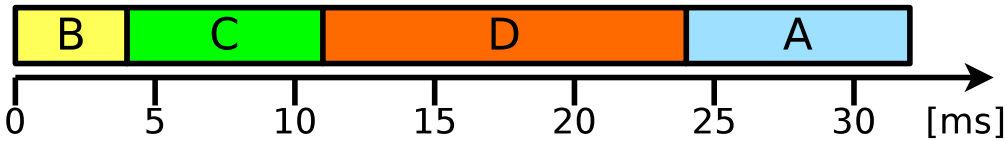

- Die Rechenzeit ist die Zeit, die der Prozess Zugriff auf die CPU benötigt, um komplett abgearbeitet zu werden
- Laufzeit = „Lebensdauer“ = Zeitspanne zwischen dem Anlegen und Beenden eines Prozesses = (Rechenzeit + Wartezeit)

Laufzeit der Prozesse

Prozess	A	B	C	D
Laufzeit	32	4	11	24

Durchschn. Laufzeit = $\frac{32+4+11+24}{4} = 17,75$ ms

Wartezeit der Prozesse

Prozess	A	B	C	D
Wartezeit	24	0	4	11

Durchschn. Wartezeit = $\frac{24+0+4+11}{4} = 9,75$ ms

First Come First Served (FCFS)

- Funktioniert nach dem Prinzip **First In First Out** (FIFO)
- Die Prozesse bekommen die CPU entsprechend ihrer Ankunftsreihenfolge zugewiesen
- Laufende Prozesse werden nicht unterbrochen
  - Es handelt sich um **nicht-präemptives** (nicht-verdrängendes) Scheduling
- FCFS ist **fair**
  - Alle Prozesse werden berücksichtigt
- Die **mittlere Wartezeit kann unter Umständen sehr hoch sein**
  - Prozesse mit kurzer Abarbeitungszeit müssen eventuell lange warten, wenn vor ihren Prozesse mit langer Abarbeitungszeit eingetroffen sind
- FCFS/FIFO eignet sich für Stapelverarbeitung ($\Longrightarrow$ Foliensatz 1)
- FIFO wird in Linux für nicht-präemptive „Echtzeitprozesse“ verwendet

Beispiel zu First Come First Served

- Auf einem Einprozessorrechner (mit nur einem CPU-Kern) sollen 4 Prozesse verarbeitet werden
- Ausführungsreihenfolge der Prozesse als Gantt-Diagramm (Zeitleiste)

Prozess	Rechenzeit	Ankunftszeit
A	8 ms	0 ms
B	4 ms	1 ms
C	7 ms	3 ms
D	13 ms	5 ms

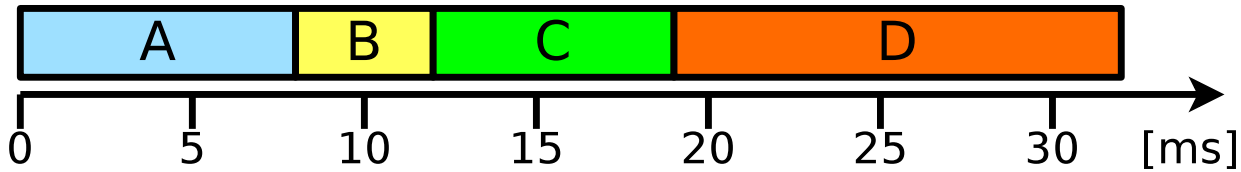

- Die Rechenzeit ist die Zeit, die der Prozess Zugriff auf die CPU benötigt, um komplett abgearbeitet zu werden
- Laufzeit = „Lebensdauer“ = Zeitspanne zwischen dem Anlegen und Beenden eines Prozesses = (Rechenzeit + Wartezeit)

Laufzeit der Prozesse

Prozess	A	B	C	D
Laufzeit	8	11	16	27

Durchschn. Laufzeit $= \frac{8+11+16+27}{4} = 15,5$ ms

Wartezeit der Prozesse

Prozess	A	B	C	D
Wartezeit	0	7	9	14

Durchschn. Wartezeit $= \frac{0+7+9+14}{4} = 7,5$ ms

Round Robin (RR) – Zeitscheibenverfahren (1/2)

- Es werden Zeitscheiben (*Time Slices*) mit einer festen Dauer festgelegt
- Die Prozesse werden in einer zyklischen Warteschlange nach dem FIFO-Prinzip eingereiht
  - Der erste Prozess der Warteschlange erhält für die Dauer einer Zeitscheibe Zugriff auf die CPU
  - Nach dem Ablauf der Zeitscheibe wird diesem der Zugriff auf die CPU wieder entzogen und er wird am Ende der Warteschlange eingereiht
  - Wird ein Prozess erfolgreich beendet, wird er aus der Warteschlange entfernt
    - Neue Prozesse werden am Ende der Warteschlange eingereiht

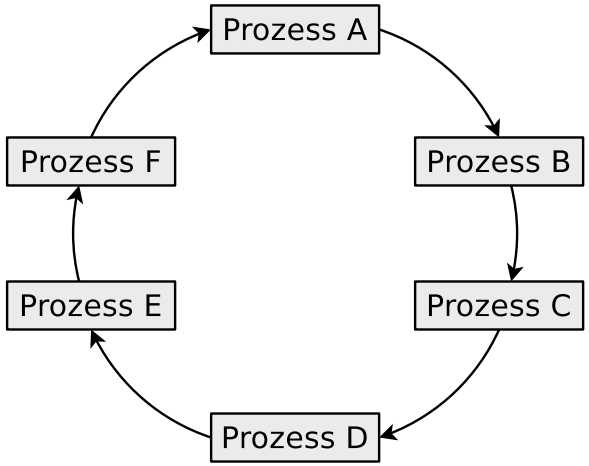

- Die Zugriffszeit auf die CPU wird **fair** auf die Prozesse aufgeteilt
- RR mit Zeitscheibengröße ∞ verhält sich wie FCFS

Round Robin (RR) – Zeitscheibenverfahren (2/2)

- Je länger die Bearbeitungsdauer eines Prozesses ist, desto mehr Runden sind für seine vollständige Ausführung nötig
- Die Größe der Zeitschlitze ist wichtig für die Systemgeschwindigkeit
  - Je kürzer sie sind, desto mehr Prozesswechsel müssen stattfinden
    $\Longrightarrow$ Hoher Overhead
  - Je länger sie sind, desto mehr geht die Gleichzeitigkeit verloren
    $\Longrightarrow$ Das System hängt/*ruckelt*
- Die Größe der Zeitschlitze liegt üblicherweise im ein- oder zweistelligen Millisekundenbereich
- **Bevorzugt Prozesse, die eine kurze Abarbeitungszeit haben**
- **Präemptives (verdrängendes) Scheduling-Verfahren**
- Round Robin Scheduling eignet sich für interaktive Systeme
- Round Robin wird in Linux für präemptive „Echtzeitprozesse“ verwendet

Beispiel zu Round Robin

- Auf einem Einprozessorrechner (mit nur einem CPU-Kern) sollen 4 Prozesse verarbeitet werden
- Alle Prozesse sind zum Zeitpunkt 0 im Zustand `bereit`
- Zeitquantum $q = 1$ ms
- Ausführungsreihenfolge der Prozesse als Gantt-Diagramm (Zeitleiste)

Prozess	Rechenzeit
A	8 ms
B	4 ms
C	7 ms
D	13 ms

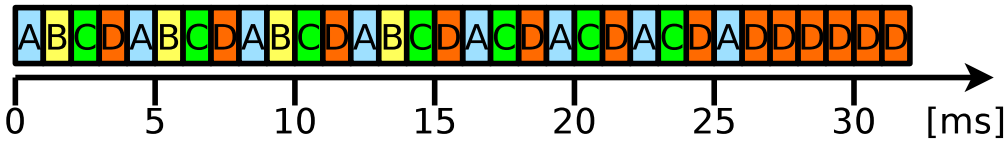

- Die Rechenzeit ist die Zeit, die der Prozess Zugriff auf die CPU benötigt, um komplett abgearbeitet zu werden
- Laufzeit = „Lebensdauer“ = Zeitspanne zwischen dem Anlegen und Beenden eines Prozesses = (Rechenzeit + Wartezeit)

Laufzeit der Prozesse

Prozess	A	B	C	D
Laufzeit	26	14	24	32

Durchschn. Laufzeit $= \frac{26+14+24+32}{4} = 24$ ms

Wartezeit der Prozesse

Prozess	A	B	C	D
Wartezeit	18	10	17	19

Durchschn. Wartezeit $= \frac{18+10+17+19}{4} = 16$ ms

Earliest Deadline First (EDF)

- Ziel: Prozesse sollen nach Möglichkeit ihre Termine zur Fertigstellung (Deadlines) einhalten
- Prozesse im Zustand `bereit` werden aufsteigend **nach ihrer Deadline geordnet**
  - Der Prozess, dessen Deadline am nächsten ist, bekommt die CPU zugewiesen
- Eine Überprüfung und gegebenenfalls Neuorganisation der Warteschlange findet statt, wenn...
  - ein neuer Prozess in den Zustand `bereit` wechselt
  - oder ein aktiver Prozess terminiert
- Kann als **präemptives und nicht-präemptives Scheduling** realisiert werden
  - Präemptives EDF eignet sich für Echtzeitbetriebssysteme
  - Nicht-präemptives EDF eignet sich für Stapelverarbeitung
- EDF wird in Linux für präemptive „Echtzeitprozesse“ verwendet

Beispiel zu Earliest Deadline First

- Auf einem Einprozessorrechner (mit nur einem CPU-Kern) sollen 4 Prozesse verarbeitet werden
- Alle Prozesse sind zum Zeitpunkt 0 im Zustand `bereit`
- Ausführungsreihenfolge der Prozesse als Gantt-Diagramm (Zeitleiste)

Prozess	Rechenzeit	Deadline
A	8 ms	25
B	4 ms	18
C	7 ms	9
D	13 ms	34

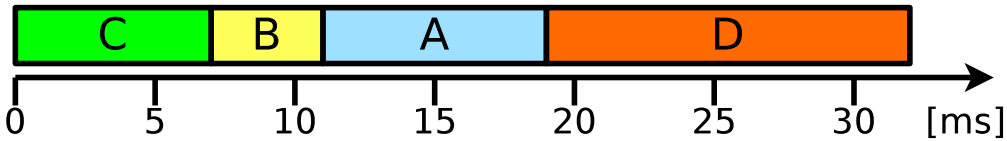

- Die Rechenzeit ist die Zeit, die der Prozess Zugriff auf die CPU benötigt, um komplett abgearbeitet zu werden
- Laufzeit = „Lebensdauer“ = Zeitspanne zwischen dem Anlegen und Beenden eines Prozesses = (Rechenzeit + Wartezeit)

Laufzeit der Prozesse

Prozess	A	B	C	D
Laufzeit	19	11	7	32

Durchschn. Laufzeit = $\frac{19+11+7+32}{4} = 17,25$ ms

Wartezeit der Prozesse

Prozess	A	B	C	D
Wartezeit	11	7	0	19

Durchschn. Wartezeit = $\frac{11+7+0+19}{4} = 9,25$ ms

Fair-Share

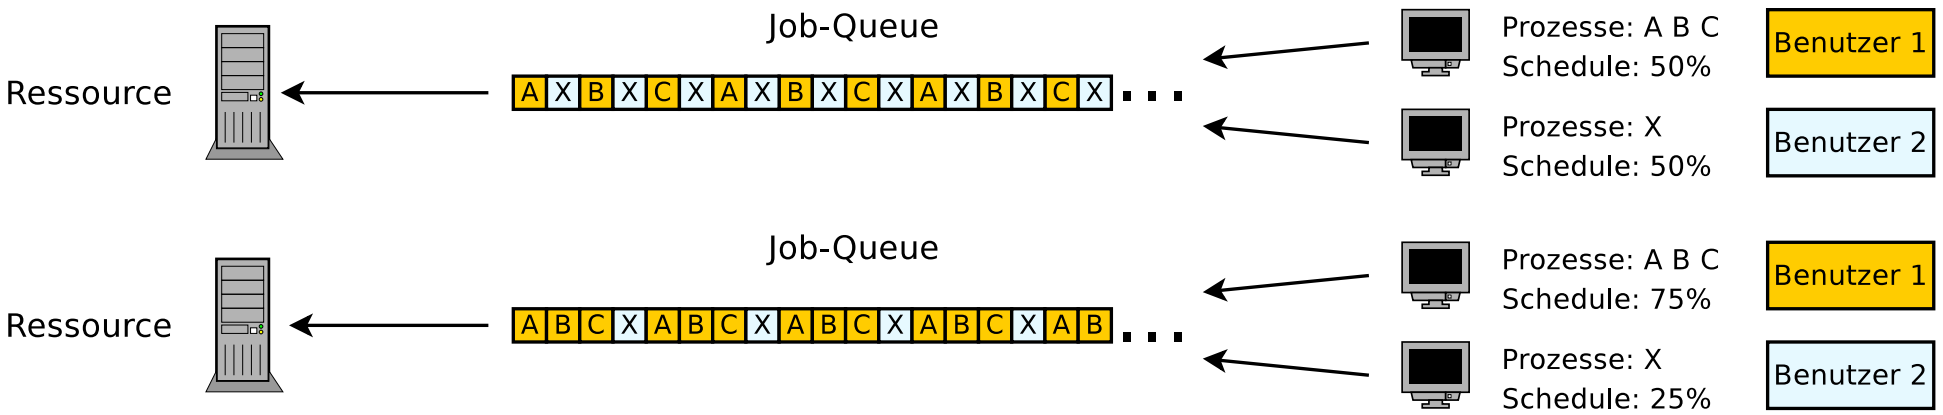

- Bei **Fair-Share** werden Ressourcen zwischen Gruppen von Prozessen in einer fairen Art und Weise aufgeteilt
- Besonderheit:
  - Die Rechenzeit wird den Benutzern und nicht den Prozessen zugeteilt
  - Die Rechenzeit, die ein Benutzer erhält, ist unabhängig von der Anzahl seiner Prozesse
- Die Ressourcenanteile, die die Benutzer erhalten, heißen Shares

Fair-Share wird häufig in Cluster- und Grid-Systemen eingesetzt

Fair-Share wird in Job-Schedulern und Meta-Schedulern (z.B. SUN/Oracle/Univa/Altair Grid Engine) zur Verteilung der Aufträge auf Ressourcen in Grid-Standorten und zwischen den Standorten in Grids eingesetzt

Multilevel-Feedback-Scheduling (1/2)

- Es ist **unmöglich, die Rechenzeit verlässlich im voraus zu kalkulieren**
  - Lösung: Prozesse, die schon länger aktiv sind, werden **bestraft**
- **Multilevel-Feedback-Scheduling** arbeitet mit mehreren Warteschlangen
  - Jede Warteschlange hat eine andere Priorität oder Zeitmultiplex (z.B. 70%:15%:10%:5%)
- Jeder neue Prozess kommt in die oberste Warteschlange
  - Damit hat er die höchste Priorität
- Innerhalb jeder Warteschlange wird Round Robin eingesetzt
  - Gibt ein Prozess die CPU freiwillig wieder ab, wird er wieder in die selbe Warteschlange eingereiht
  - Hat ein Prozess seine volle Zeitscheibe genutzt, kommt er in die nächst tiefere Warteschlange mit einer niedrigeren Priorität
    - Die Prioritäten werden bei diesem Verfahren also **dynamisch** vergeben
- Multilevel-Feedback-Scheduling ist **unterbrechendes Scheduling**

Multilevel-Feedback-Scheduling (2/2)

- Vorteil:
  - **Keine komplizierten Abschätzungen!**
    - Neue Prozesse werden schnell in eine Prioritätsklasse eingeordnet
- **Bevorzugt neue Prozesse gegenüber älteren** (länger laufenden) Prozessen

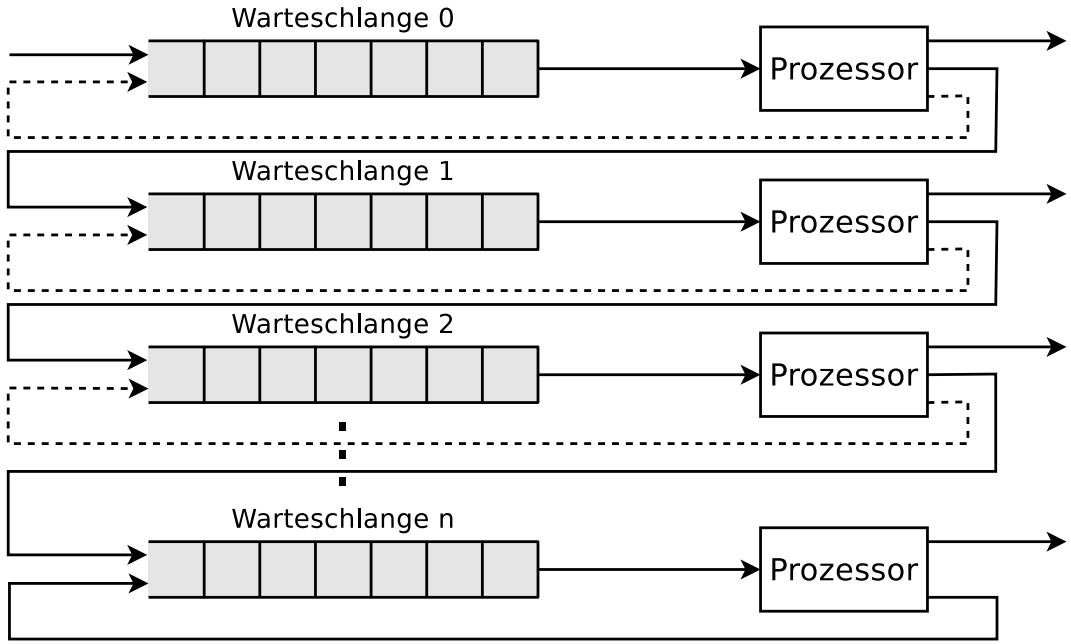

- Prozesse mit vielen Ein-/Ausgabeoperationen werden bevorzugt, weil sie nach einer freiwilligen Abgabe der CPU wieder in die ursprüngliche Warteliste eingeordnet werden $\Longrightarrow$ Dadurch behalten Sie ihre Priorität
- Ältere, länger laufende Prozesse werden verzögert

Quelle: William Stallings. Betriebssysteme. 4. Auflage. Pearson (2003). S.479

Viele moderne Betriebssysteme verwenden für das Scheduling der Prozesse Varianten des Multilevel-Feedback-Scheduling.
Beispiele: Linux für „normale“ Prozesse (bis Kernel 2.4), Mac OS X, FreeBSD und die Windows NT-Familie

Completely Fair Scheduler (Linux seit 2.6.23) – Teil 1/4

- Der Kernel realisiert für jeden CPU-Kern einen CFS-Scheduler und verwaltet für jeden `SCHED_OTHER` Prozess eine Variable **vruntime** (virtual runtime)
  - Der Wert repräsentiert eine virtuelle Prozessorlaufzeit in Nanosekunden

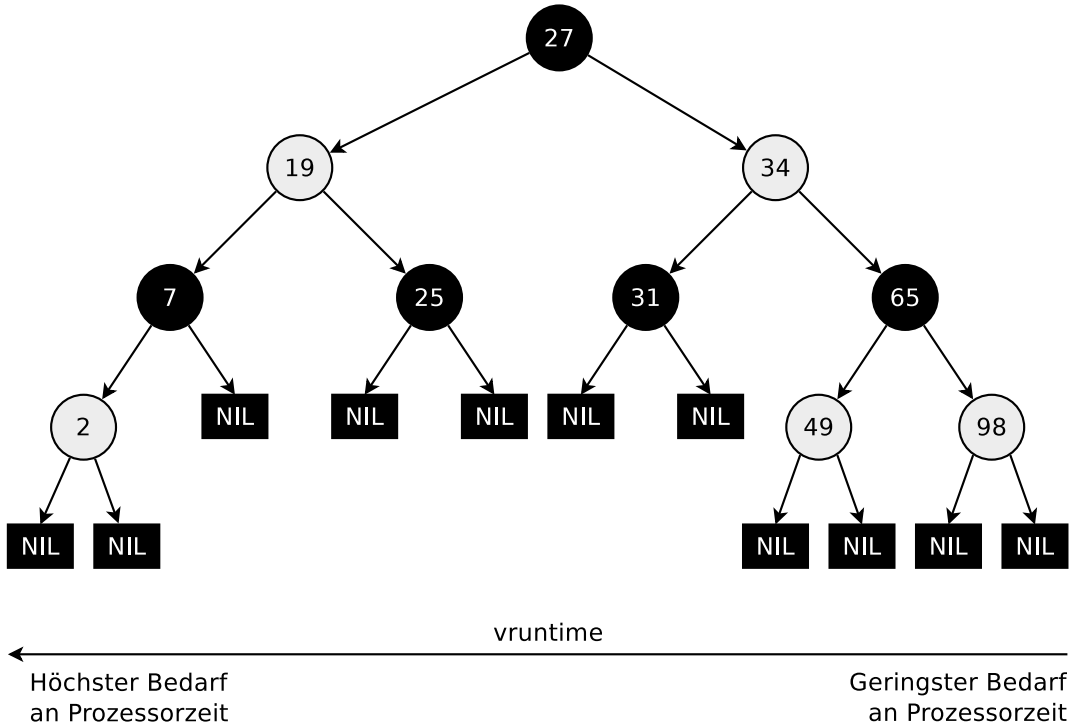

- vruntime sagt aus, wie lange der jeweilige Prozess schon gerechnet hat
  - Der Prozess mit der niedrigsten vruntime bekommt als nächstes Zugriff auf den CPU-Kern
- Die Verwaltung der Prozesse geschieht mit Hilfe eines **Rot-Schwarz-Baums** (selbstbalancierender binärer Suchbaum)
  - Die Prozesse sind anhand der vruntime-Werte einsortiert

Completely Fair Scheduler (Linux seit 2.6.23) – Teil 2/4

- Ziel: Alle Prozesse, die einem CPU-Kern zugeordnet sind, sollen einen ähnlich großen (fairen) Anteil Rechenzeit erhalten
  $\Longrightarrow$ Bei n Prozessen soll jeder Prozess $1/n$ der Rechenzeit erhalten

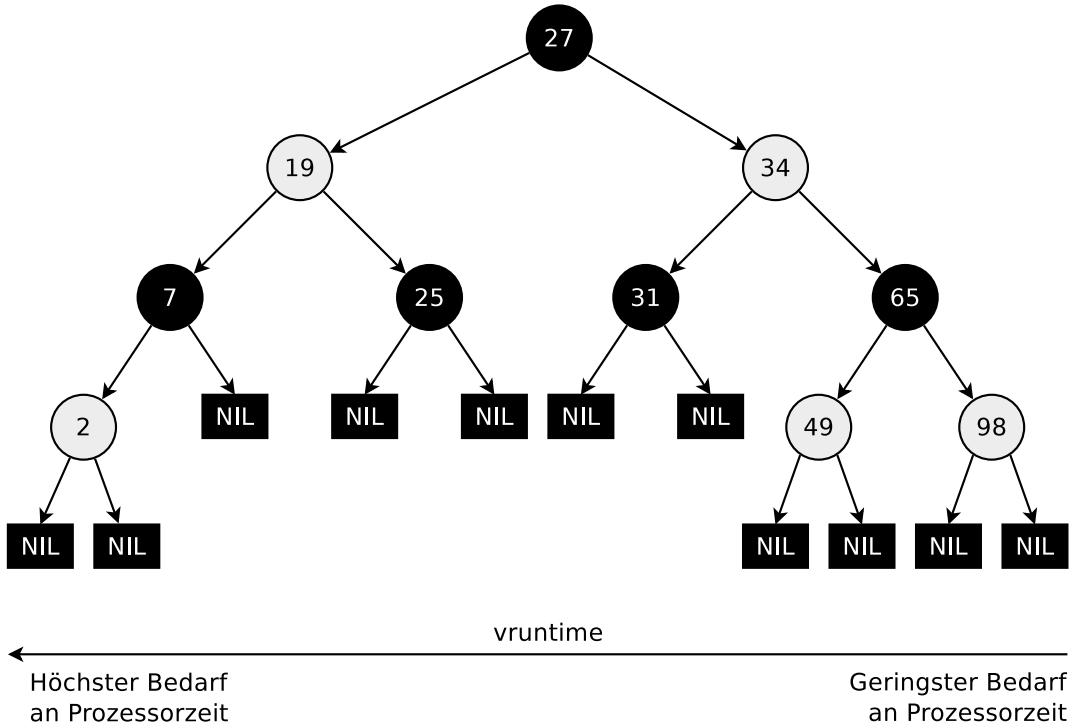

- Hat ein Prozess Zugriff auf den CPU-Kern, darf er so lange rechnen, bis sein vruntime-Wert sich dem angestrebten Anteil von $1/n$ der verfügbaren Rechenzeit angenähert hat
- Der Scheduler strebt einen gleichen vruntime-Wert für alle Prozesse an

Der CFS-Scheduler kümmert sich nur um die Ablaufplanung der „normalen“ Prozesse, die der Prozessklasse `SCHED_OTHER` zugeordnet sind

Completely Fair Scheduler (Linux seit 2.6.23) – Teil 3/4

- Die Werte sind die Schlüssel der inneren Knoten
- Blattkonten (NIL-Knoten) haben keine Schlüssel und enthalten keine Daten
- NIL steht für *none*, *nothing*, *null*, also für einen Null-Wert oder Null-Pointer

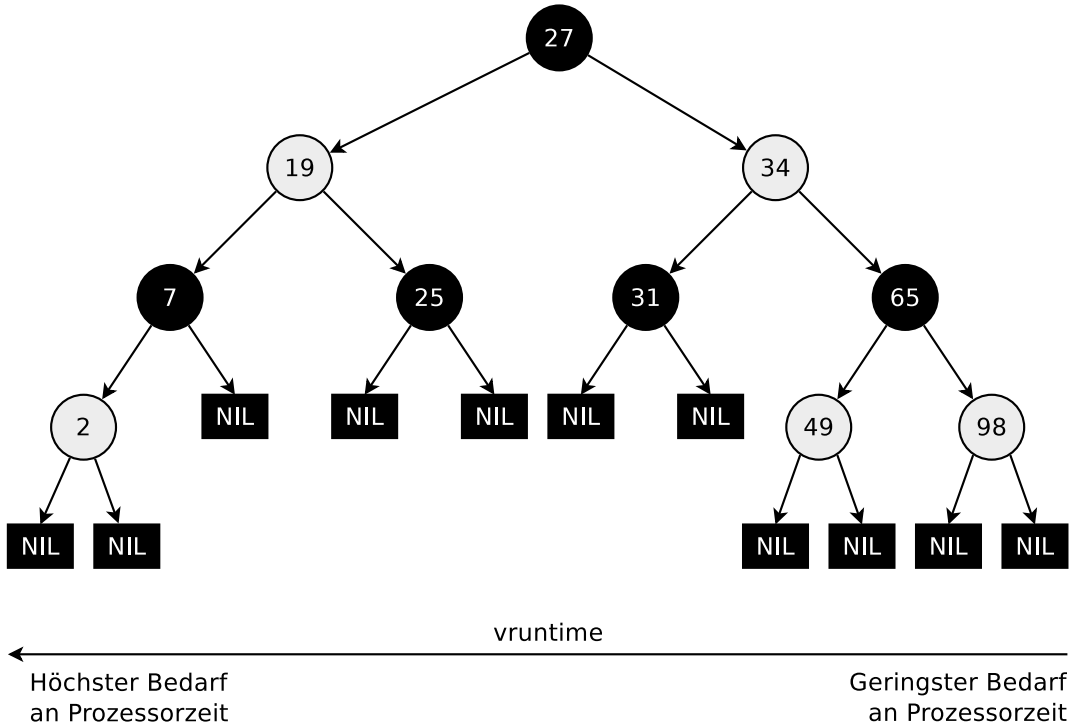

- Aus Fairnessgründen weist der Scheduler dem Prozess ganz links im Baum als nächstes den CPU-Kern zu
- Wird ein Prozess vom CPU-Kern verdrängt, erhöht sich der vruntime-Wert um die Zeit, die der Prozess auf dem CPU-Kern gelaufen ist

Completely Fair Scheduler (Linux seit 2.6.23) – Teil 4/4

- Die Knoten (Prozesse) im Baum wandern kontinuierlich von rechts nach links
  $\Longrightarrow$ Das gewährleistet die faire Verteilung der Rechenleistung

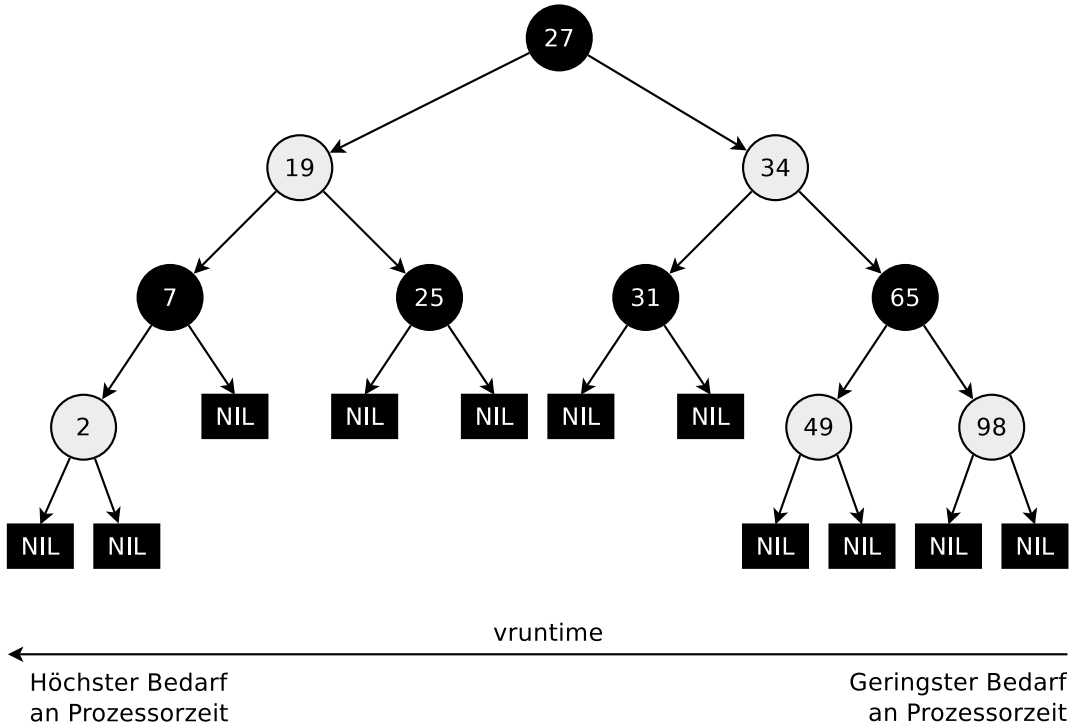

- Der Scheduler berücksichtigt die statischen Prozessprioritäten (`nice`-Werte) der Prozesse
- Die vruntime-Werte werden abhängig vom `nice`-Wert unterschiedlich gewichtet
  - Anders gesagt: Die virtuelle Uhr kann unterschiedlich schnell laufen

Earliest Eligible Virtual Deadline First – Teil 1/4

- Der Linux-Kernel seit v6.6 verwendet EEVDF anstelle von CFS
- Der EEVDF-Scheduler kombiniert das Fairness-Konzept von CFS (Completely Fair Scheduler) mit Deadline-basiertem Scheduling wie EDF (Earliest Deadline First) aus Echtzeitsystemen
- **CFS und EEVDF beide...**
  - zielen darauf ab, allen Prozessen einen **gleichen (fairen) Anteil** der Rechenzeit des CPU-Kerns, dem sie zugewiesen sind, bereitzustellen
  - verwenden die statischen Prozessprioritäten (`nice`-Werte), um die **virtuelle Uhr (`vruntime`) unterschiedlich schnell laufen zu lassen**
- EEVDF führt für jeden Prozess einige neue Werte ein:
  - **Lag** („Verzögerung“), **Eligibility** („Eignung“), **Eligible time** („Zeit bis zur Eignung“), **virtuelle Deadline**

Einige interessante Quellen zu EEVDF

An EEVDF CPU scheduler for Linux. *Jonathan Corbet* (März 2023). `https://lwn.net/Articles/925371/`
EEVDF Patch Notes. *Kuanch* (August 2024). `https://hackmd.io/@Kuanch/eevdf`
Thinking about eevdf. *Chunyu* (August 2024). `https://chunyu.sh/blog/thinking-about-eevdf/`
EEVDF Scheduler. *The kernel development community*. `https://docs.kernel.org/next/scheduler/sched-eevdf.html`

Earliest Eligible Virtual Deadline First – Teil 2/4

- Mit EEVDF verwaltet der Kernel einen **Lag**-Wert für jeden Prozess
  - Der Lag eines Prozesses ist die Differenz von idealer (berechneter) CPU-Zeit, die er hätte bekommen sollen, und der erhaltenen Zeit
  - Lag $< 0 \Longrightarrow$ dem Prozess wurde zu viel CPU-Zeit zugewiesen
  - Lag $\geq 0 \Longrightarrow$ der Prozess hat seinen fairen Anteil Zeit nicht erhalten
    - Nur Prozesse mit positivem Lag sind zur Ausführung geeignet (**eligible**)
  - Nutzen der Verwaltung von Lag und Eignung (Eligibility): **Mehr Fairness**

Quelle: `https://chunyu.sh/blog/thinking-about-eevdf/`

Lag eines Prozesses = aktuelle gewichtete Prozesslaufzeit (vruntime) - gewichteter Durchschnitt der Prozesslaufzeiten (vruntime) aller Prozesse

- Die nächste Folie enthält ein Beispiel, das die Berechnung der Prozessverzögerung veranschaulicht
  - Im Beispiel sind 3 Prozesse demselben CPU-Kern zugewiesen und starten zur gleichen Zeit
    $\Longrightarrow$ Zu Beginn haben sie alle einen Lag mit dem Wert Null

Earliest Eligible Virtual Deadline First – Teil 3/4

Quelle dieses Beispiels: **Completing the EEVDF scheduler**. *Jonathan Corbet* (April 2024). `https://lwn.net/Articles/969062/`

Prozess	A	B	C
lag [ms]	0	0	0
Eligible	ja	ja	ja

- Kein Prozess hat einen negativen Lag $\Longrightarrow$ alle sind geeignet
- Annahme: Alle Prozesse haben die gleiche statische Priorität (`nice`-Wert) und die Zeitscheibenlänge ist für jeden Prozess 30 ms
- Annahme: Der Scheduler legt fest, dass A zuerst läuft, und A läuft über die gesamte Zeitscheibe

Prozess	A	B	C
lag [ms]	-20	10	10
Eligible	nein	ja	ja

- Jeder Prozess erhält 1/3 der gesamten CPU-Zeit (10 von 30 ms)
  $\Longrightarrow$ A ist 30 ms gelaufen, also ist sein Lag -20 ms
  $\Longrightarrow$ B und C sind nicht gelaufen und haben jeder 10 ms Lag
- Annahme: Der Scheduler legt fest, dass B als Nächstes läuft, und B läuft über die gesamte Zeitscheibe

Prozess	A	B	C
lag [ms]	-10	-10	20
Eligible	nein	nein	ja

- Jeder Prozess erhält 1/3 der gesamten CPU-Zeit (10 von 30 ms)
  $\Longrightarrow$ B ist 30 ms gelaufen, also ist sein Lag -10 ms
  $\Longrightarrow$ C ist nicht gelaufen und hat nun 20 ms Lag
- Der Scheduler wird als nächstes C auswählen

Die Summe aller Lag-Werte der Prozesse, die einem CPU-Kern zugeordnet sind, entspricht immer dem Wert Null

Earliest Eligible Virtual Deadline First – Teil 4/4

- EEVDF verwaltet eine **virtuelle Deadline** für jeden Prozess
  - Der Prozess mit der kürzesten Deadline, der für eine Ausführung in Frage kommt (Eligibility), läuft als nächstes
    - Die virtuelle Deadline wird mit der **Eligible time** für den Prozess und dessen **Zeitscheibenlänge** (abhängig von der statischen Priorität = `nice`-Wert) berechnet
- **Eligible time**
  - Zur Erinnerung: Prozesse mit ...
    - Lag ≥ 0 sind zur Ausführung geeignet
    - Lag < 0 wurde zu viel CPU-Zeit zugewiesen und sind daher nicht zur Ausführung geeignet
  - EEVDF berechnet für jeden nicht geeigneten Prozess seine **Eligible time**, d.h. den Zeitpunkt, zu dem er wieder geeignet wird
- Nutzen der virtuellen Deadline: **Bessere Latenz** für Echtzeit- und interaktive Prozesse

EEVDF soll im Vergleich zu CFS fairer sein und bessere Latenzzeiten bieten

Klassische und moderne Scheduling-Verfahren

	Scheduling NP	Scheduling P	Fair	Rechenzeit muss bekannt sein	Berücksichtigt Prioritäten
Prioritätengesteuertes Scheduling	X	X	nein	nein	ja
First Come First Served = FIFO	X		ja	nein	nein
~~Last-Come-First-Served~~	~~X~~	~~X~~	~~nein~~	~~nein~~	~~nein~~
Round Robin		X	ja	nein	nein
~~Shortest/Longest-Job-First~~	~~X~~		~~nein~~	~~ja~~	~~nein~~
~~Shortest-Remaining-Time-First~~		~~X~~	~~nein~~	~~ja~~	~~nein~~
~~Longest-Remaining-Time-First~~		~~X~~	~~nein~~	~~ja~~	~~nein~~
~~Highest-Response-Ratio-Next~~	~~X~~		~~ja~~	~~ja~~	~~nein~~
Earliest Deadline First	X	X	ja	nein	nein
Fair-Share		X	ja	nein	nein
~~Statisches Multilevel-Scheduling~~		~~X~~	~~nein~~	~~nein~~	~~ja (statisch)~~
Multilevel-Feedback-Scheduling		X	ja	nein	ja (dynamisch)
~~O(1)-Scheduler~~		~~X~~	~~ja~~	~~nein~~	~~ja~~
Completely Fair Scheduler		X	ja	nein	ja
Earliest Eligible Virtual Deadline First		X	ja	nein	ja

- NP = Nicht-präemptives Scheduling, P = Präemptives Scheduling
- Ein Schedulingverfahren ist „fair“, wenn jeder Prozess irgendwann Zugriff auf die CPU erhält
- Es ist unmöglich, die Rechenzeit verlässlich im voraus zu kalkulieren

Linux 2.6.0 bis 2.6.22 verwendet den **O(1)-Scheduler**. Dieser spielt aus Zeitgründen hier keine Rolle
`https://www.ibm.com/developerworks/library/l-scheduler/index.html`